

**ДОСЛІДЖЕННЯ МЕТОДУ ВЗАЄМНОГО ЗЛИТТЯ РАНГІВ
У МЕТОДАХ КОЛАБОРАТИВНОЇ ФІЛЬТРАЦІЇ
РЕКОМЕНДАЦІЙНИХ СИСТЕМ НА ОСНОВІ
НЕЯВНОГО ЗВОРОТНОГО ЗВ'ЯЗКУ**

Бухало В.О., Мінухін С.В.

e-mail: volodymyr.bukhalo@nure.ua, serhii.minukhin@nure.ua

Харківський національний університет радіоелектроніки, каф. КМІТ
м. Харків, Україна

The study investigates the application of the RRF method in CF tasks of recommendation systems for combining the results of different recommendation algorithms. The RRF method is used within the late fusion strategy for the formation of a single ordered list of recommendations based on the results of the following algorithms: ALS, BPR, BiVAE, LightGCN, NCF, and SAR. The experimental evaluation covers fifteen pairwise combinations of algorithms, different in their construction principles, tested on the MovieLens 100K dataset and two subsets of datasets from the Amazon Reviews'23 collection (Video Games and Movies and TV) converted to the implicit feedback format. The experimental results demonstrate that applying the RRF method in the late fusion strategy mostly improves the metrics for the formation and ordering of recommendation lists compared with using individual recommendation algorithms.

У сучасному цифровому світі, коли обсяг інформації та доступного матеріалу надзвичайно великий, рекомендаційні системи (РС) відіграють важливу роль у полегшенні процесу вибору продуктів, послуг та контенту для користувачів [1]. Колаборативна фільтрація (CF) є однією із найбільш поширених стратегій побудови РС [2] та формує рекомендації, використовуючи вподобання користувачів із подібними смаками. Надання високоякісних рекомендацій має вирішальне значення для персоналізації та підвищення рівня залученості, оскільки їх використання сприяє зростанню задоволеності аудиторії завдяки релевантним пропозиціям [3, 4].

У задачі CF метод взаємного злиття рангів (RRF) визначає підсумкову оцінку об'єкта як суму рангів у кількох незалежно сформованих списках рекомендацій. Завдяки цьому об'єкти, що займають вищі позиції, отримують більший внесок у підсумковий результат. Метод дозволяє поєднувати результати різних алгоритмів на основі позицій у списках, незалежно від абсолютних значень оцінок, що забезпечує коректну інтеграцію результатів [5].

Метою роботи є дослідження впливу методу RRF на якість формування і впорядкування списків рекомендацій у задачах CF

рекомендаційних систем шляхом попарного поєднання результатів рекомендаційних алгоритмів за стратегією пізнього злиття [6].

Для коректного застосування **стратегії пізнього злиття** використано розширений набір кандидатів рекомендацій. З цією метою кожен рекомендаційний алгоритм формує впорядкований список рекомендацій більшої довжини, ніж підсумковий список, що використовується для оцінювання якості, і забезпечує включення достатньої кількості об'єктів для їх подальшого об'єднання методом RRF (1):

$$K_{\text{розш}} = K + B, \quad (1)$$

де $K_{\text{розш}}$ – кількість елементів розширеного набору кандидатів рекомендацій для подальшого застосування методу RRF; K – кількість елементів у підсумковому списку, що оцінюється; B – кількість додаткових рекомендацій.

Для інтеграції результатів у межах стратегії пізнього злиття використано зважене узагальнення класичного RRF для будь-яких двох алгоритмів CF, обраних для попарного злиття їхніх результатів:

$$s(u, i) = 1[i \in A] \frac{w_A}{k_0 + r_A(u, i)} + 1[i \in B] \frac{1 - w_A}{k_0 + r_B(u, i)}, \quad (2)$$

де $s(u, i)$ – підсумковий агрегований бал об'єкта i для користувача u ; $1[i \in A], 1[i \in B]$ – індикаторні функції, що дорівнюють 1, якщо об'єкт i присутній у списку рекомендацій відповідного алгоритму, і 0 – у протилежному випадку; $r_A(u, i), r_B(u, i)$ – ранги об'єкта i у списках рекомендацій алгоритмів A та B ; $w_A \in (0, 1)$ – ваговий коефіцієнт алгоритму A , що визначає частку впливу результатів першого алгоритму на підсумковий агрегований бал; $1 - w_A$ – компліментарний ваговий коефіцієнт алгоритму B , що автоматично визначає залишковий вплив другого алгоритму, забезпечуючи умову нормалізації, де сума ваг дорівнює 1; k_0 – параметр згладжування, що визначає вплив позиції об'єкта на підсумковий бал.

Зважене узагальнення класичного RRF дозволяє інтегрувати довільну кількість алгоритмів шляхом додавання відповідних доданків у (2), за умови, що сума всіх вагових коефіцієнтів має дорівнювати 1 для забезпечення нормалізації підсумкового балу.

Параметр вагового коефіцієнту алгоритму A та параметр згладжування підбиралися перебірним пошуком на основі Grid Search окремо для кожної пари алгоритмів. Оптимальна конфігурація визначалася шляхом максимізації нормалізованого дисконтованого кумулятивного виграшу (nDCG) у топ- K рекомендаціях:

$$(w_A^*, k_0^*) = \arg \arg nDCG@K(w_A, k_0), \quad (3)$$

де $w_A \in \{0, 1, 0, 2, \dots, 0, 9\}$; $k_0 \in \{10, 20, \dots, 100\}$.

Попарне злиття результатів рекомендацій здійснювалося для таких алгоритмів: методу найменших квадратів (ALS) у конфігурації для неявного зворотного зв'язку, байєсівського персоналізованого ранжування (BPR), двостороннього варіаційного автоенкодера (BiVAE), легкої графової згорткової мережі (LightGCN), нейронної CF (NCF) та простого алгоритму рекомендацій (SAR). Такий вибір зумовлений необхідністю **залучення різних за способом побудови алгоритмів**, що застосовуються в реальних РС.

Тестування проводилося на наборі даних MovieLens 100K (розрідженість 93,70%) [6], а також на двох підмножинах наборів даних колекції Amazon Reviews'23 (Video Games і Movies and TV) [7]. Підмножини було сформовано шляхом уніфікації даних, фільтрації невалідних і дубльованих записів, а також застосування k-core фільтрації з мінімальною кількістю взаємодій для користувачів і об'єктів, що забезпечило виділення стабільних підмножин взаємодій – Video Games 15-core з розрідженістю 97,97% та Movies and TV 25-core з розрідженістю 97,18%. Усі набори даних **приведено до формату неявних відгуків** користувачів шляхом бінаризації рейтингів за пороговим значенням. Значення рейтингів перетворювалися відповідно до правила:

$$\tilde{r}_{ui} = \{1, \quad r_{ui} \geq 4, \quad 0, \quad r_{ui} < 4, \quad , \quad (4)$$

де r_{ui} – початковий рейтинг, наданий користувачем u об'єкту i ; $\tilde{r}_{ui}$ – бінаризований сигнал неявної взаємодії, що використовувався для уніфікованого проведення експериментів.

Порогове значення було обрано з урахуванням того, що в обраних наборах даних рейтинги задані за п'ятибальною шкалою від 1 до 5, яка утворює впорядковану множину цілих значень $\{1, 2, 3, 4, 5\}$, де значення 3 є її медіаною та інтерпретується як нейтральна оцінка, а значення 4 було обрано як поріг для відокремлення позитивного сигналу від нейтрального або негативного [8].

У результаті було здійснено повний перебір 15 попарних комбінацій алгоритмів на трьох наборах даних та виміряно для них відносне покращення значень таких метрик: якості формування та впорядкування списків рекомендацій: середнього значення середньої точності: MAP, nDCG, точності (Precision) та повноти (Recall), – обчислених для перших десяти позицій рекомендаційного списку, порівняно з кращим базовим алгоритмом у парі.

Для MovieLens 100K максимальне збільшення значення відносного відхилення за метрикою nDCG становить 15,74% для пари ALS і NCF (MAP +24,21%, Precision +15,12%, Recall +9,50%), при цьому додатне відносне відхилення за nDCG спостерігається для всіх 15 пар алгоритмів. Для Amazon Reviews'23 Video Games 15-core додатне відносне відхилення за nDCG зафіксовано у 11 із 15 пар, з максимальним значенням 6,75% для BiVAE і LightGCN (MAP +8,18%, Precision +5,79%, Recall +6,31%). Для Amazon Reviews'23 Movies and TV 25-core покращення за значенням

nDCG спостерігається у 13 із 15 пар, з максимальним значенням 8,79% для ALS і NCF (MAP +7,44%, Precision +9,96%, Recall +9,47%). У двох останніх наборах даних спостерігаються поодинокі від'ємні відносні відхилення nDCG, MAP, Precision і Recall, які є незначними та наближаються до нуля.

Таким чином, використання методу RRF для комбінації двох різних алгоритмів CF у більшості випадків забезпечує покращення значень метрик якості формування та впорядкування списків рекомендацій порівняно з кращим алгоритмом з певної пари, що досліджувалися, й може застосовуватися для підвищення якості рекомендацій, які отримує кінцевий користувач системи.

Список використаних джерел:

1. Hyeyoung Ko, Suyeon Lee, Yoonseo Park and Anna Choi. A Survey of Recommendation Systems: Recommendation Models, Techniques, and Application Fields <https://www.mdpi.com/2079-9292/11/1/141> . DOI: <https://doi.org/10.3390/electronics11010141>.
2. Li Y. A Review of Collaborative Filtering Recommendation Systems. European Journal of AI, Computing & Informatics. 2025. Vol. 1, no. 1. P. 1–11.
3. He X., Liu Q., Jung S. The Impact of Recommendation System on User Satisfaction: A Moderated Mediation Approach. Journal of Theoretical and Applied Electronic Commerce Research. 2024. Vol. 19, no. 1. P. 448–466. DOI: <https://doi.org/10.3390/jtaer19010024>
4. Ситнікова П. Е. Рекомендаційна система на основі компактної гібридної моделі користувача / П. Е. Ситнікова, М. О. Гребенюк // АСУ та прилади автоматики : всеукраїнський міжвідомчий науково-технічний збірник. – ХНУРЕ. – 2023. – Вип. 179. – С. 32–42. – DOI: <https://doi.org/10.20837/0135-1710.2023.179.032>
4. Cormack G.V., Clarke C.L.A., Büttcher S. Reciprocal Rank Fusion Outperforms Condorcet and Individual Rank Learning Methods. Proc. SIGIR, 2009.
5. Yilma B. A., Leiva L. A. MOSAIC: Multimodal Multistakeholder-aware Visual Art Recommendation. arXiv preprint. 2024. arXiv:2407.21758. URL: <https://arxiv.org/abs/2407.21758> (date of access: 20.02.2026).
6. MovieLens. GroupLens. URL: <https://grouplens.org/datasets/movielens/> (date of access: 28.01.2026).
7. Amazon Reviews'23. Amazon Reviews'23. URL: <https://amazon-reviews-2023.github.io/index.html> (date of access: 28.01.2026).
8. Variational Autoencoders for Collaborative Filtering. arXiv.org. URL: <https://arxiv.org/abs/1802.05814> (date of access: 29.01.2026).